

## 4 Q-11

## ニューラルネットワークを用いた知識獲得と洗練

麻生川 稔

日本電気(株) C&amp;C システム研究所

asogawa@csl.cl.nec.co.jp

## はじめに

実用的なエキスパートシステムの構築では、知識の獲得と洗練が重要な課題となっている。演繹学習の一つの方式として、説明による学習(EBL:Explanation-based Learning)がある。EBLでは、あらかじめ得られている領域知識を用いて例題を証明し、証明過程の一般化を知識として獲得する。EBLでは領域知識が完全であると仮定しているが、実際には完全な知識を予め得ることは難しい。他の知識獲得方法として、ニューラルネットワークの学習能力を用いて記号による学習を補強しようとする試みがある[Shavlik 89][石川 90]。この方法では、領域知識が不完全であっても対応できるなどの利点がある。本論文では、EBLに於いて、従来法の問題点を改善したニューラルネットワークによる知識獲得と洗練の方法を提案する。

## 1 従来法

## 1.1 EBLでのニューラルネットワーク学習

Shavlikらは、EBLとニューラルネットワーク学習を比較している[Shavlik 89]。ニューラルネットワークを用いた学習では、予め与えられた領域知識を局所表現を用いて階層型ニューラルネットワークにマッピングしている。

中間層の各セルは、各中間概念に対応させている。領域知識の各ルールは、それに対応するリンクの重みを大きくし、それに応じて中間層のバイアスを調整することによってマッピングしている。ニューラルネットワークに例題を提示しバックワードプロパゲーション(誤差逆伝搬法)を用いる。ここでの問題点は、例題を証明するのに必要な中間概念が領域知識に含まれていない場合は、学習できない可能性があることである。

この様に表現された領域知識を、例題を提示しバックワードプロパゲーションを用いて洗練する。局所表現を用いているため、洗練された知識は視察により容易に抽出できる。予め領域知識をニューラルネットワークに展開してあるので、領域知識を持たないニューラルネットワークに比較して、学習がよりすみやかに修了すると期待される。ここで、展開した領域知識はほぼ完全なものであるべく保存すべきである。しかしながら、Shavlikらはそのような配慮をしていない。そのため、バックワードプロパゲーションによって領域知識が否定される可能性がある。

Knowledge Acquisition and Refinement  
Using Neural Network,  
Minoru ASOGAWA, C&C Systems Research Laboratories,  
NEC Corporation

## 1.2 ニューラルネットワークによる論理関数の学習

石川は、階層型ニューラルネットワークを用いて論理関数を学習が行なえることを示した[石川 90]。ここでの学習では、EBLの場合とは異なり、領域知識を用いない。従来の方式では、中間層の各セルの意味付けが明確化されていないので、バックワードプロパゲーションを用いた学習では獲得された知識は分散表現される。分散表現された知識は、視察によっては容易に解釈できない。

中間層の各セルの意味付けが明確化される様に、石川はバックワードプロパゲーションに於いてコスト関数として、従来から用いられている2乗誤差とニューラルネットワークの複雑度と中間層表現の局所度を加味したものをを用いた。従って、学習に於いては、出力の2乗誤差を減少させると同時に、中間層での表現が局所的になるように行なわれる。このコスト関数を用いたバックワードプロパゲーションにより得られたニューラルネットワークでは、知識が局所表現されているため、リンクの重みの解釈が容易となっていることが実験によって示されている。しかしながら、この方法では全ての入力に対して、中間層のセルの出力が常に活性または非活性となることがあり得る<sup>1</sup>。

## 2 提案するニューラルネットワークによるEBL

ここで提案する方式は、EBLに於ける学習で、Shavlikらの知識表現方式と石川のコストの評価関数を組合せ、従来の問題点を解決したものである。これによって、以下のことが可能となる。

- 領域知識が不完全であっても対応可能。
- 予め展開された領域知識をなるべく保存する様に学習。
- 領域知識には含まれないが、例題には含まれる知識の獲得が可能。
- 後向き推論が可能。

## 2.1 領域知識のマッピング法

提案する方式の領域知識のマッピング法は、Shavlikらが用いている方法と同じである。すなわち、知識は局所表現を用いて階層型のニューラルネットワークにマッピングする。中間層の各セルは、各中間概念に対応させる。また、領域知識に含まれていない中間概念の表現を可能とするために、中

<sup>1</sup>これは、中間層表現の局所度の評価として、セルの出力が、活性または非活性のどちらかに近付けば評価が良くなる様になっている為である。この様な学習では、中間層が出力に影響を及ぼさなくなる可能性がある。秋山らはこの状況を避けるために、石川の評価関数の符号を換えたものに似たものを使っている[秋山 91]。

間層に中間概念以外に対応するセルを加えておく。全てのセル間にはリンクを定義し、領域知識の各ルールに対応するリンクの重みを大きくし、バイアスを調整する。

## 2.2 ニューラルネットワーク学習

学習は、例題を提示しバックワードプロパゲーションを用いる。展開した領域知識をなるべく保存するように、バックワードプロパゲーションのコスト関数として、2乗誤差と領域知識の保存度の和を用いる。領域知識の保存度  $E^p$  は以下の様に決める。

$$E^p = \sum_{i,j} |w_{i,j}^{init} - w_{i,j}| \quad (1)$$

ここで、 $w_{i,j}^{init}$  は領域知識を展開した直後のリンクの重み、 $w_{i,j}$  はリンクの重み。実際には、バックワードプロパゲーションを始める前に  $w_{i,j}^{init}$  にも小さな範囲の乱数を重畳させる。ここで、コストには重みの差の絶対値を用いているが、差の2乗なども用いることができる<sup>2</sup>。これによって、バックワードプロパゲーションでは、展開した領域知識をなるべく保存するよう出来る。

## 2.3 中間層のマッピングのチェック方法

例題を提示しバックワードプロパゲーションにより知識の洗練が行なわれるが、中間層のセルがすべての入力に対しても常に活性あるいは非活性になる可能性がある。これをチェックする方法としては、全ての例題の提示に対して、中間層で常に活性あるいは非活性となっているセルをチェックすれば出来る。この方法では、例題が多い場合には、計算量が多くなる。

そこで、各セルへの重みベクトル ( $w$ ) とバイアス ( $\theta$ ) が構成する超平面が、入力ベクトル ( $x$ ) が取り得る空間をに含まれるかを調べる方式を提案する。この方式では、各中間セルについて調べれば良いので、計算量が少ない。

この方式をおおざっぱに説明する。まず、入力ベクトルの平均 ( $\bar{x}$ ) と超平面との距離 ( $d$ ) を求める<sup>3</sup>。この距離が入力ベクトルの分散 ( $\sigma$ ) の3倍以上であれば、入力の空間に超平面が含まれず、セルの出力が常に活性あるいは非活性となっている可能性があるとする。

## 2.4 知識の抽出

知識は局所表現を用いているため、中間層の各セルは各中間概念に対応している。従って、領域知識はリンクの重みの大きいものとして表現されている。また、中間層で中間概念以外に対応するセルに対してのリンクの重みが大きい時は、それに対して人手によって意味づけをして知識として抽出する。

<sup>2</sup>これらのコスト関数のバリエーションについては、[石川 90] が詳しい。

<sup>3</sup> $d$  と超平面のパラメータ  $w$  と  $\theta$  の関係は、 $d = \frac{w\bar{x} + \theta}{|w|}$  で与えられる。

## 2.5 後向き推論

従来、階層型ニューラルネットワークの記号処理への応用では、前向き推論のみが行なわれてきた。提案する方法ではニューラルネットワークを用いて後向き推論も可能である。以下、これについて説明する。

全ての入力に分かっていなくても、学習後のニューラルネットワークに入力の一部を提示すると、出力が得られる。入力の情報が十分でないと、確信のある出力が得られない(出力値が  $-1.0$  または  $1.0$  に達しない)ことがある。出力を確信のあるものにするために必要な入力を示す手法を以下に示す。これはニューラルネットワークを用いたパターン認識手法 [麻生川 91] の記号処理への応用である。

1. 学習後のニューラルネットワークに現在得られている入力値を与える。
2. 前向き伝搬(フォワードプロパゲーション)で出力値を計算する。
3. 出力セルの出力値を参考に、仮の正解を決める<sup>4</sup>。
4. 仮の正解と現在の出力値の2乗誤差  $Error$  を計算し、それをバックワードプロパゲーションし、入力層の各セルの  $\delta$  ( $= -\frac{\partial Error}{\partial net}$ ) を求める<sup>5</sup>。 $\delta$  は、 $Error$  に対する入力値 ( $net$ ) の偏微分係数の符号を換えたもので、 $\delta$  に従って入力を変更すると  $Error$  が減少する。
5. 分かっている入力のうちの、最大のデルタを持つものに対して、入力値を得て、その値を入力セルにセットする。
6. エラーが小さい値に収束するまで、上記の手続きを繰り返す。これによって、出力(仮説)をサポートするのに必要な入力(証拠)を収集することができ、後向き推論が可能となる。

## 3 まとめ

ニューラルネットワークによる知識獲得と洗練の方法を示した。この方法では、EBL に於いて、領域知識が不完全であっても対応でき、新たに領域知識を獲得でき、またそれによって後向き推論も可能となることを示した。

## 参考文献

- [Shavlik 89] Shavlik et. al., "An Approach to Combining Explanation-based and Neural Learning Algorithms", Connection Science, Vol. 1, No. 3, pp. 231-251 (1989).  
 [石川 90] 石川, "忘却を用いたコネクショニストモデルの構造学習アルゴリズム", 人工知能学会誌, Vol. 5, No. 5, pp. 595-603, (1990).  
 [秋山 91] 秋山 他, "エントロピー項を付加したバックプロパゲーション学習則", 情処全大 6G-4, (1991).  
 [麻生川 91] 麻生川, "入力領域適応型ニューラルネットワークの収束性と応用例", 情処全大 6G-7, (1991).

<sup>4</sup>簡単な方法は、出力値が正ならば  $1.0$ 、負ならば  $-1.0$  とする。

<sup>5</sup>リンクの重みは固定であり、バックワードプロパゲーションは入力層の各セルの  $\delta$  を求める為に行なうことを注意しなくてはならない。